

WEEKLY REPORT

严凡

Mararch 3,2019

1. 上周工作

1.1 尝试 RNN 网络搭建，测试自己生成语句的效果

理由: RNN 具有处理有序内容的神经网络。我做器官分割。分割的器官图片其实是一套 2D 图片的结合。可以假设成是一套视频。所以如果能够在切割网络里加上 rnn 说不定可以提高我的精度。提取出器官图片连续性的这一个特点。

总结: 感觉可行。不过关于如何把 rnn 和 u-net 结合起来就是个难点问题了。由于下周开始要开始辅助张建伟学长做实验，他忙着要发论文。所以我这方面尝试可能要先延后下。

1.2 学习论文

看了两片论文并写了汇报 ppt，下周在开会时去进行汇报

1.3 写开题报告，文献翻译，综述完善

毕业论文里面需要。学校里要开始上交了。就花了些时间在这方面

2. 论文阅读


2.1 Attention U-Net: Learning Where to Look for the Pancreas

创新点:

1. 基于网格的门控，使注意系数更加特定于局部区域。与基于全局特征向量的门控相比，提高了性能。此外，我们的方法可用于密集预测，因为

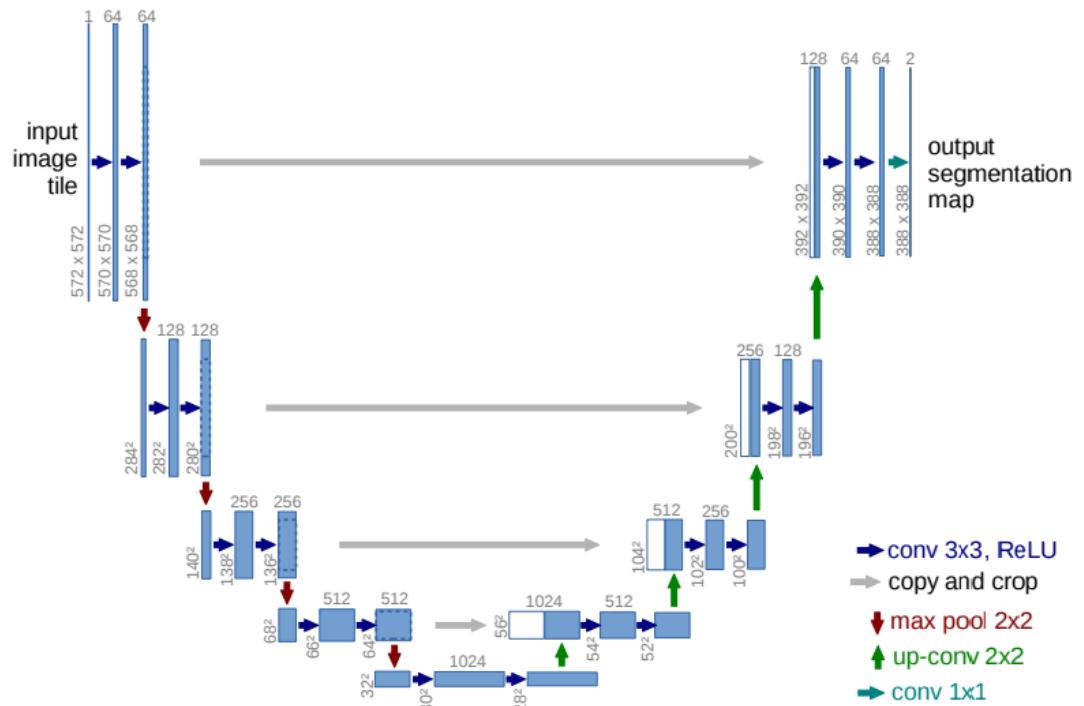
我们不执行自适应池化。

2. 提出的注意力门可以取代图像分类中使用的硬注意方法和图像分割框架中的外部器官定位模型
3. 提高模型对前景像素的灵敏度，而无需复杂的启发式算法。 通过实验观察到 U-Net 的准确度改进 在不同的图像数据集中是一致的

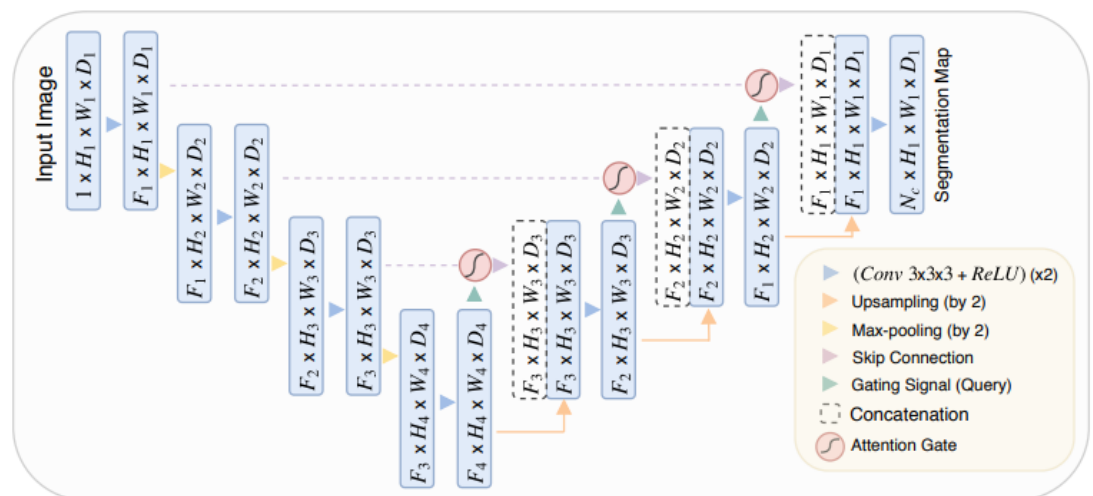


如图所示: 从左到右 (a-e , f-j) : 3D 腹部 CT 扫描的轴向和矢状视图 , 注意系数 , 门控连接前后跳过连接的特征激活。类似地 , (k-n) 在粗尺度跳过连接上可视化门控。从多个 AG 收集过滤的特征激活 (d-e , i-j) , 其中每个门选择器官的子集。 (d-e , i-j) 中所示的激活一致地对应于不同扫描的特定结构。

与标准 u-net 模型的框架相比较



U-NET 框架



Attention U-Net

输入图像逐渐过滤，并在网络编码部分的每个比例下采样 2 倍（例如 $H_4 = H_1 / 8$ ） N_c 表示类的数量。注意门（AG）过滤通过跳过连接传播的特征。AG 的原理图如图 2 所示。通过使用在较粗尺度中提取的上下文信息（门控）来实现 AG 中的特征选择性， F_1 代表对应层特征映射的数量

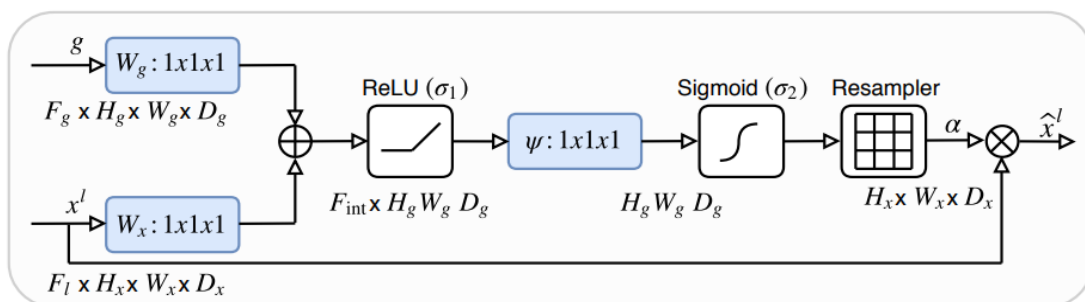
可见整个模型的之间最大的改变就是加了一层关注门。那么这个关注门的具体实现

方式就是如下这个公示:

$$q_{att}^l = \psi^T \left(\sigma_1 \left(W_x^T x_i^l + W_g^T g_i + b_g \right) \right) + b_\psi \quad (1)$$


$$\alpha_i^l = \sigma_2 \left(q_{att}^l(x_i^l, g_i; \Theta_{att}) \right), \quad (2)$$

用图式的方法演示这个公示就是如下样子



输入特征 (x 1) 用在 AG 中计算的关注系数 (α) 来缩放。通过分析由较粗规模收集的
门控信号 (g) 提供的激活和上下文信息来选择空间区域。使用三线性插值完成
注意系数的网格重采样

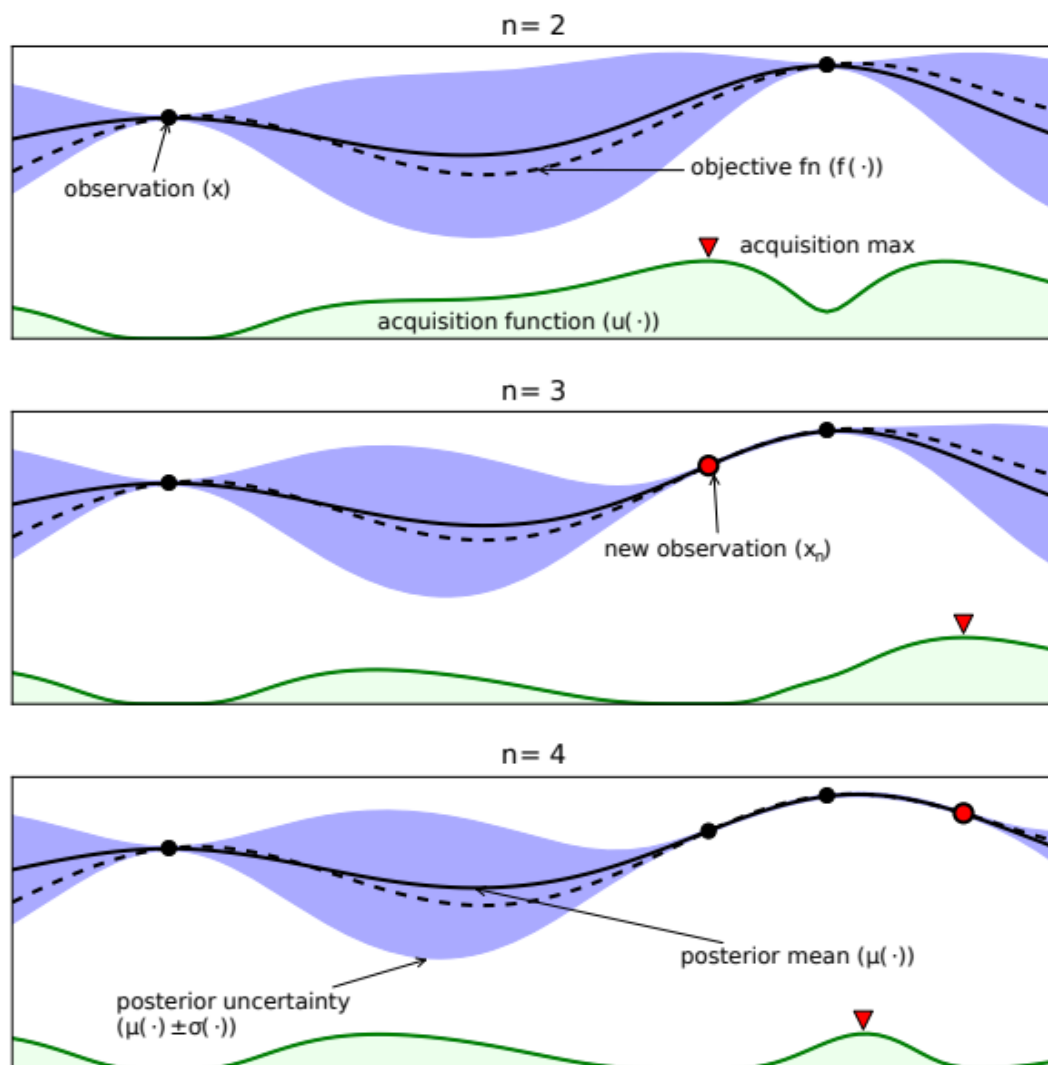
最后这是把 attention u-net 用于腹部 CT 多类分割的结果。可见切割的效果还是
不错的。



2.2 Taking the Human Out of the Loop: A Review of Bayesian Optimization

这篇文章主要讲的是贝叶斯优化器。

贝叶斯优化器主要用在机器学习中可以自动调节参数。可以更快去自动寻找到最好的最优的参数值和模型决策的选择。



先介绍下这张图的前提条件:

1. $f(x)$ 是未知的，而通过提高更多的真实样本 $[x,y]$ 来修正猜测的 $f(x)$ 接近目标函数
2. Observation (x) 是已经观察过的点
3. 虚线是目标函数
4. 蓝色阴影部分是先验函数，基于概率分布，(假设是高斯分布，不同的概率模型

对结果的影响很大

5. 实线是高斯分布中最高点

6. 绿色的地方是收益函数

然后具体的动态内容是: $n=2$ 时 取收益函数最高点的 X 。就是 $n=3$ 时需要带入运算得出 Y 的点, 以此来修正概率函数并接近目标函数的真实分布


可见贝叶斯优化主要重点在于两个地方:

1. 先验函数

2. 获取函数

文章由于是综述, 所以就是介绍了很多相关的工作

1. 关于先验函数



带参模型

1. Thompson sampling

in the Beta-Bernoulli bandit model

2. Linear models

3. Generalized linear model

非参模型

1. The Gaussian process

2. Common kernels

3. Prior mean functions

4. Marginal likelihood

5. Computational costs and other regression models

2. 获取函数

就是用于查询下一个需要获取样本 $[x,y]$ 的位置

这里就讲究着一个开发和探索的决策了

- **1. 开发**：在明确的曲线上扬方向继续走，大概率获得更好的结果，但是容易陷入局部最优。

- **2. 探索**：除了在曲线上扬的方向，在其它的区域也不忘寻找

1. Improvement-based policies

这种方法的基本思想是选择收益最高的点。

包括如

probability of improvement(PI)、

expected improvement(EI)等方式

2. Optimistic policies

这种方法主要采用上限置信区间

(upper confidence bound)

方法是

Gaussian process upper confidence bound (GP-UCB)

3 Information-based policies

此类方式思想是利用后验信息来进行选点。

常用有 Thompson sampling 和 entropy search(ES)。

基于熵的方法减少不确定性为主，

有一些相关工作都有用到这个

4. Portfolios of acquisition functions

这类方法就是将多种 AC 方法进行集成 ,

最近的工作比如有 ESP

通过考虑信息的增益来选择不同的候选者

3. 讨论了几个实际和实现细节


1. Handling hyperparameters

用正交或蒙特卡罗的方法

2. Optimizing acquisition functions

Simultaneous optimistic optimization(SOO)

The Bayesian multi-scale SOO (BamSOO)



通过分割具有高函数值或置信上限的叶子来顺序构建空间分区树;然后在所选叶子的中心评估目标函数。

3. Conditional Spaces

通过变量和变量之间的依赖性和变量的取值空间

提供了联合优化框架的可能性

4. 非平稳性过程

已经尝试通过积分 GP 内核的幅度参数来稳健地实现这种效果。这在 [Practical Bayesian optimization of machine learning algorithms]中以数字方式完成，并在[138]中使用共轭先验进行分析，得到具有 t 分布预测和输入相关噪声协方差的潜在 GP

5. 并行

下周任务

1. 配合张建伟学长做实验
2. 抽空做做毕业设计

工作时长 $(10+12+8+10+8+0+0)=48$ 小时